

文章编号:1672 - 058X(2013)02 - 0026 - 05

快速有效的全局和局部能量驱动的活动轮廓模型^{*}

段立涛

(重庆大学 数学与统计学院,重庆 401331)

摘要:由全局和局部拟合能量驱动的活动轮廓模型(LGIF 模型)对活动轮廓的初始化和噪声不敏感,且能够分割灰度不均匀图像;但是该模型的演化方程在每次迭代中需要进行多次高斯卷积,使得分割速度非常慢;基于这一缺点提出了一个新的模型;实验表明:该模型不仅能够分割灰度不均匀图像,而且分割效率优于 LGIF 模型。

关键词:图像分割;活动轮廓模型;LGIF 模型

中图分类号:TP911. 73

文献标志码:A

近年来,基于偏微分方法的图像分割得到了广泛的应用,特别是活动轮廓模型已经成为图像分割的主要方法之一。活动轮廓模型主要分为基于边缘的模型和基于区域的模型。主要研究基于区域的模型,文献[1]提出了著名的活动轮廓模型(称 CV 模型)。用分片常数函数近似代替待分割图像来提取目标边缘。它的优点是对活动轮廓的初始化不敏感,且对噪声具有鲁棒性;但是,它不能处理灰度不均匀的图像,造成这一缺点的原因是模型本身假设图像只由两种不同灰度的区域组成,这种假设非常简单,而现实中存在大量灰度不均图像。为了处理灰度不均图像,许多研究者提出了新的模型以及许多改进模型,如参考文献[2-6]。其中文献[2-3]提出了一种区域可变的活动轮廓模型(称 LBF 模型)。把 CV 模型的全局二值拟合能量泛函改为以高斯函数为核函数的可变区域拟合能量定义的能量泛函,较好地克服了 CV 模型不能分割灰度不均匀图像的困难。然而对活动轮廓的初始化很敏感,并且演化速度很慢,这就限制了它的实际应用。为了克服 LBF 模型的缺点,文献[5]结合 CV 模型和 LBF 模型的优点提出了一个新的模型(称 LGIF 模型)。模型从能量泛函入手,将其定义为全局能量项和局部能量项的一个线性组合,通过适当选择组合系数,模型能够分割灰度不均匀图像,并较好解决了 LBF 模型对初始曲线的位置敏感的问题。然而此模型也存在缺点,它的局部能量项演化时需要进行多次高斯卷积,这就使得计算复杂度很大,在结合 CV 能量项后计算量进一步加大。在此针对文献[5]中模型的缺点,提出了一个新的模型。构造一个新的局部拟合能量项,它在演化过程中比原来的局部拟合能量项的计算减少了一半的高斯卷积次数,从而极大地提高了演化速度。

1 研究背景

1.1 CV 模型

CV 模型假设图像 I 由两个同质区域组成,其由水平集表示的能量泛函:

收稿日期:2012 - 09 - 10;修回日期:2012 - 10 - 08.

* 基金项目:中央高校基本科研业务费资助(DJXS11100042).

作者简介:段立涛(1987-),男,山东济宁人,硕士研究生,从事偏微分方程与图像处理研究.

$$\begin{aligned} E^{\text{CV}} &= \lambda_1 \int_{\Omega} |I - c_1|^2 H(\varphi) dx + \lambda_2 \int_{\Omega} |I - c_2|^2 (1 - H(\varphi)) dx + \nu \int_{\Omega} \delta(\varphi) |H(\varphi)| dx \\ &= E^{\text{GIF}} + \nu L(\varphi) \end{aligned} \quad (1)$$

其中, φ 是零水平集, c_1 和 c_2 是分别是图像区域在演化曲线内部和外部的灰度平均值, $\delta(\varphi)$ 和 $H(\varphi)$ 分别是 Dirac 函数和 Heaviside 数, E^{GIF} 称为全局能量项, $L(\varphi)$ 为曲线长度项。

CV 模型基于图像的全局信息, 因此对活动轮廓的初始化不敏感, 且对噪声具有鲁棒性。但是由于它假设图像是由两个近似于常值的区域组成, 所以无法分割灰度不均图像。

1.2 LBF 模型

与 CV 模型不同, LBF 模型是一种基于区域可变的局部拟合能量。其由水平集表示的局部能量泛函形式:

$$\mathcal{E}^{\text{Fit}}(\varphi, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_i(x)|^2 M_i(\varphi) dy \quad (2)$$

其中, $M_1(\varphi) = H(\varphi)$, $M_2(\varphi) = 1 - H(\varphi)$, λ_1 和 λ_2 为正整数, $f_i(x)$ 为图像在点 x 处的局部拟合值, K_{σ} 为 $\sigma > 0$ 的高斯核函数。

将当前点 x 延伸到整个区域, 同时为了确保水平集 φ 演化的稳定性, 增加了距离正则化项^[7]。因此, 总的能量泛函可以写成如下公式:

$$\begin{aligned} E^{\text{LBF}} &= \int_{\Omega} \mathcal{E}^{\text{Fit}} dx + \nu \int_{\Omega} \delta(\varphi) |H(\varphi)| dx + \frac{1}{2} \mu \int_{\Omega} (|\nabla \varphi| - 1)^2 dx = \\ &= E^{\text{LIF}} + \nu L(\varphi) + \mu P(\varphi) \end{aligned} \quad (3)$$

其中, $L(\varphi)$ 为曲线长度项, $P(\varphi)$ 为距离正则项, E^{LIF} 为局部能量项, μ 和 ν 为非负常量。

在 LBF 模型中, f_1 和 f_2 近似于轮廓内外高斯窗内的灰度的加权平均值。它利用了局部图像信息, 因此对灰度不均匀图像有很好的分割效果。但是由于没有涉及全局信息, 所以对曲线的大小和初始位置很敏感。

1.3 LGIF 模型

LGIF 模型是由 Wang 等人提出来的, 该模型结合了 CV 模型和 LBF 模型的优点, 它的能量泛函是全局能量项和局部能量项的一个线性组合, 其能量泛函形式如下:

$$E^{\text{LGIF}}(\varphi, c_1, c_2, f_1, f_2) = \omega E^{\text{GIF}} + (1 - \omega) E^{\text{LIF}} + \nu L(\varphi) + \mu P(\varphi) \quad (4)$$

其中, f_2 和 ν 为非负常量。 ω 为常量并且满足 $0 \leq \omega \leq 1$ 。

关于上述能量泛函固定 φ , 分别对 c_1, c_2, f_1, f_2 极小化, 得到 c_1, c_2, f_1, f_2 的表达式如下:

$$c_1 = \frac{\int I(x) H(\varphi) dx}{\int H(\varphi) dx} \quad (5)$$

$$c_2 = \frac{\int I(x) (1 - H(\varphi)) dx}{\int 1 - H(\varphi) dx} \quad (5)$$

$$\begin{aligned} f_1(x) &= \frac{K(x) * (I(x) H(\varphi))}{K(x) * H(\varphi)} \\ f_2(x) &= \frac{K(x) * (I(x) (1 - H(\varphi)))}{K(x) * (1 - H(\varphi))} \end{aligned} \quad (6)$$

根据变分法和梯度下降法, 得到关于水平集的演化方程:

$$\frac{\partial \varphi}{\partial t} = -\delta_{\varepsilon}(\varphi) (F_1 + F_2) + \nu \operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right) + \mu (\Delta \varphi - \operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right)) \quad (7)$$

其中,

$$\begin{aligned} F_1 &= \omega(\lambda_1(I - c_1)^2 - \lambda_2(I - c_2)^2) \\ F_2 &= (1 - \omega)(\lambda_1 \int K_\sigma(x - y)(I(y) - f_1(x))^2 - \lambda_2 \int K_\sigma(x - y)(I(y) - f_2(x))^2) \end{aligned} \quad (8)$$

在 LGIF 模型中,参数 ω 控制全局能量项和局部能量项的权重,当图像灰度不均匀程度严重时, ω 应该取较小值,使得局部能量项起主要作用;当图像灰度不均匀程度较轻时, ω 应该取较大值,从而全局能量项起主要作用。因此对活动轮廓的初始化不敏感。但是由于局部能量项在演化过程中每迭代一次需要进行多次高斯卷积,所以计算复杂度增大,导致演化速度很慢。针对这一缺点,在此提出了一个新的模型。

2 模型建立

2.1 模型描述

受文献[5]的启发,构造一个新的局部拟合能量泛函,其由水平集表示的形式:

$$E^{\text{ILIF}} = \sum_{i=1}^2 \int_{\Omega} \lambda_i |I(x) - f_i(x)|^2 M_i(\varphi) dx \quad (9)$$

其中, $f_1(x)$ 、 $f_2(x)$ 分别由式(7)、(8)表示。同时为了克服活动轮廓初始化的敏感性,结合全局拟合能量构成总的能量泛函:

$$E^{\text{ILGIF}} = \omega E^{\text{GIF}} + (1 - \omega) E^{\text{ILIF}} + \nu L(\varphi) + \mu P(\varphi) \quad (10)$$

对能量泛函(12)式用梯度下降法求解得到最终曲线演化方程:

$$\frac{\partial \phi}{\partial t} = -\delta_\varepsilon(\phi)(F'_1 + F'_2) + \nu \delta_\varepsilon(\varepsilon)(\phi) \operatorname{div}\left(\frac{\nabla \phi}{|\nabla \phi|}\right) + \mu\left(\Delta \phi - \operatorname{div}\left(\frac{\nabla \phi}{|\nabla \phi|}\right)\right) \quad (11)$$

其中,

$$\begin{aligned} F'_1 &= \omega(\lambda_1(I(x) - c_1)^2 - \lambda_2(I(x) - c_2)^2) \\ F'_2 &= (1 - \omega)(\lambda_1(I(x) - f_1(x))^2 - \lambda_2(I(x) - f_2(x))^2) \end{aligned} \quad (12)$$

2.2 模型的进一步分析

本文模型与 LGIF 模型相比计算复杂度低,因为模型中局部能量项的计算量远远小于 LGIF 模型中局部能量项的计算量,这可以从 F'_2 和 F_2 的对比得出结论, F'_2 的计算量主要是 f_1 和 f_2 的计算,利用如下式子简化 f_1 和 f_2 :

$$\begin{aligned} f_1(x) &= \frac{K(x) * (I(x)H(\varphi))}{K(x) * H(\varphi)} \\ f_2(x) &= \frac{K(x) * I(x) - K(x) * (I(x)H(\varphi))}{K(x) * 1 - K(x) * H(\varphi)} \end{aligned} \quad (13)$$

其中, f_2 中的 $K(x) * I(x)$ 与 $K(x) * 1$ 是常数,在整个演化过程中只计算一次,而 f_1 和 f_2 共用 $K(x) * (I(x)H(\varphi))$ 和 $K(x) * H(\varphi)$,每次演化只需分别计算一次,假设高斯模板的窗口大小为 $n \times n$,图像的像素为 N ,则每次演化中 f_1 和 f_2 总的计算量为 $O(n^2N)$ 。将 F_2 展开并合并同类项得:

$$F_2 = (1 - \omega)((\lambda_1 - \lambda_2)I^2(x)[K_\sigma * 1] - 2I(x)[K_\sigma * (\lambda_1 f_1 - \lambda_2 f_2)] + K_\sigma * (\lambda_1 f_1^2 - \lambda_2 f_2^2)) \quad (14)$$

上式右边第一项为常数,整个演化过程中只需计算一次,第二项和第三项除了计算 f_1 和 f_2 还要计算两次高斯卷积,因此总的计算量为 $O(n^4N)$ 。因为实验过程中 σ 一般取 3 以上,而高斯模板窗口一般选取 $n \geq 4\sigma$ (见文献[2-3]),因此 $O(n^4N) \geq O(n^2N)$,从而本文模型计算量远远小于 LGIF 模型计算量。

3 实验结果与分析

本文实验结果表明:能够分割灰度不均图像;与 LGIF 模型进行了对比,分割效率优于 LGIF 模型。本文算法的参数如无特别说明设置为 $\sigma = 3.0, \lambda_1 = \lambda_2 = 1.0$, 时间步长 $\Delta t = 0.1, \mu = 1.0, \nu = 0.001 \times 255 \times 255, \omega$ 选取 0.01。实验环境为 Windows 7, Pentium 双核 T4400 CPU 2.20 GHz。

(1) 实验 1。本文模型对灰度不均分割结果。图 1 显示了一幅人造图像(88×85)和三幅医学图像的分割结果($102 \times 114, 244 \times 183$ 和 74×74),实验结果是令人满意的。前两幅文献[2]已经采用,后两幅也是典型的灰度不均图像。

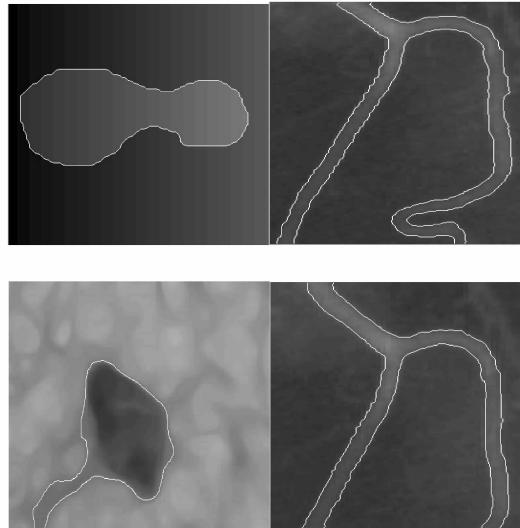


图 1 灰度不均匀图像

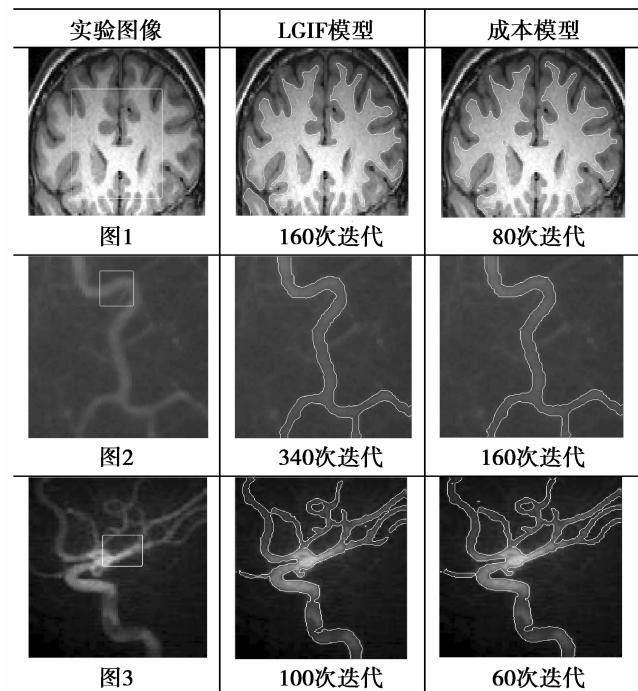


图 2 本文模型与 LGIF 分割效率的比较

(2) 实验 2。分割效率的对比。图 2 为对三幅灰度不均图像的分割结果与迭代次数,第一幅图像取 $\nu = 0.004 \times 255^2, \lambda_2 = 2$ 。实验结果表明本文模型收敛速度和分割效率优于 LGIF 模型。

为了比较 LGIF 模型和本文模型的计算效率,表 1 给出了两个模型对实验 3 中三幅图像的迭代次数和 CPU 时间。从表中可以看出,本文模型比 LGIF 模型节约超过 50% 的时间。

表 1 两个模型的迭代次数和运行时间(s)

图像序号	LGIF 模型		本文模型	
	迭代次数	t/s	迭代次数	t/s
1	160	10.16	80	3.96
2	340	25.70	160	8.70
3	100	7.63	60	3.34

4 结束语

本文构造一个新的局部拟合能量,在结合全局拟合能量形成了一个新的由全局和局部拟合能量驱动的活动轮廓模型,实验结果表明该模型分割效率上优于 LGIF 模型。

参考文献:

- [1] CHAN T F, VESE L A. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277
- [2] LI C, KAO C Y, GORE J C, et al. Implicit active contours driven by local binary fitting energy [C] // Proc. of IEEE Conference on Computer Vision and Pattern Recognition. Minnesota, USA: [s. n.], 2007: 1-7
- [3] LI C, KAO C Y, GORE J C, et al. Minimization of region-scalable fitting energy for image segmentation [J]. IEEE Transactions on Image Processing, 2008, 17(2): 1940- 1949
- [4] 张森,陈永革. 基于参数法的3种研制费用估算模型[J]. 四川兵工学报,2010(3):53-55
- [5] WANG L, LI C, SUN Q, et al. Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation [J]. Computerized Medical Imaging and Graphics, 2009, 33: 520-531
- [6] 原野,何传江. LBF 活动轮廓模型的改进[J]. 计算机工程与应用,2009,45(15): 177-179
- [7] LI C, XU C, GUI C, et al. Level set evolution without re- initialization: A new variational Formulation [C] // Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005, 1:430-436

Fast and Efficient Active Contours Driven by Local and Global Intensity Fitting Energy

DUAN Li-tao

(College of Mathematics and Statistics, Chongqing University, Chongqing 401331, China)

Abstract: Active contours driven by local and global intensity fitting energy (LGIF model) is much less sensitive to the initialization of the contours and noise, and it can address the segmentation of images with intensity inhomogeneity. However, the evolution equation of this model needs many Gaussian convolutions per iteration, which make the segmentation speed extremely slow. We propose an improved model based on the aforementioned fault. The experiments show that the model is not only able to deal with intensity inhomogeneity, but also the segmentation efficiency is more efficient than LGIF model.

Key words: image segmentation; active contours model; LGIF model

责任编辑:代小红